

تولید متن با رویکرد جمعی مبتنی بر شبکه‌های مولد مقابله‌ای

احسان منتهائی و مهدیه سلیمانی باغشاه

اصلی را کاملاً یاد بگیرد و بسته به تابع هزینه رفتارهای متفاوتی را بروز می‌دهد. رفتاری که با تابع هدف درست‌نمایی بروز داده می‌شود باعث می‌شود توزیع آموزش‌دیده یا یاد گرفته شده، کل توزیع داده اصلی را در بر بگیرد و در این بین ممکن است به نقاطی از فضا بیشترین احتمال را نسبت دهد که داده‌های اصلی در آنجا احتمال کمی دارند. این رفتار را جستجوی میانگین^۲ نامیده می‌شود. در حوزه مدل‌های مولد این رفتار به این معنی است که مدل می‌خواهد داده‌هایی شبیه به تمام داده‌های آموزش تولید کند، حتی به این قیمت که بعضی از داده‌های تولیدی شبیه به داده‌های آموزش نباشند [۱].

شبکه‌های مولد مقابله‌ای^۳ (GANs) [۲] می‌توانند استفاده از تابع هدف‌های مناسب‌تر را ممکن کنند [۱]. راهکارهای زیادی برای استفاده از یادگیری مقابله‌ای در حوزه داده‌های پیوسته خصوصاً در کاربرد تولید تصویر پیشنهاد و استفاده شده است، ولی به دلیل مشکل انتقال گرادیان مستقیماً امکان استفاده از این روش‌ها در حوزه داده‌های گسسته وجود ندارد [۳].

برای به روز رسانی شبکه مولد^۴ در شبکه‌های مولد مقابله‌ای (GAN) لازم است که نمونه‌های تولیدشده توسط شبکه مولد وارد دسته‌بند یا شبکه تمیزدهنده^۵ شده، سپس با کمک دسته‌بند تغییر پارامترهای شبکه مولد در جهتی که شبکه دسته‌بند فریب بخورد، صورت گیرد. برای این که گرادیان نسبت به پارامترهای شبکه مولد قابل محاسبه باشد، باید تمام عملیات ایجاد نمونه و محاسبه خروجی دسته‌بند دارای مشتق تعریف شده باشند. در مسأله تولید متن در انتهای شبکه مولد نیاز به نمونه‌گیری از یک توزیع است، این عملیات مشتق مناسبی ندارد که این موضوع باعث بروز مشکل انتقال گرادیان می‌شود [۴].

بیشتر پژوهش‌های پیشین برای استفاده از شبکه‌های مولد مقابله‌ای در تولید دنباله به موضوع رفع مشکل انتقال گرادیان اختصاص داشته است. رویکردهای مختلفی برای این منظور وجود داشته است. برخی از روش‌ها به صورت تقریبی گرادیان انتقال یافته به مولد را به دست می‌آورند. راه حل دیگر که رایج‌تر است، تبدیل مسأله آموزش مولد به یک مسأله یادگیری تقویتی است. این روش‌ها با تعیین پاداش برای مولد آموزش را انجام داده و گرادیان شبکه مولد را از این طریق محاسبه می‌کنند. در این دسته از پژوهش‌ها هدف دیگری که دنبال می‌شود، افزایش اطلاعات موجود در پاداش است. همچنین برخی از پژوهش‌ها سعی کرده‌اند با تغییر صورت مسأله و تبدیل آن به مسأله‌ای پیوسته، تولید دنباله را انجام دهند. در این مقاله قصد داریم روشی برای تولید دنباله ارائه کنیم که بر پایه شبکه‌های مولد مقابله‌ای است، اما با مشکلاتی نظیر انتقال گرادیان روبه‌رو نیست. برای این منظور از یک رویکرد تکرارشونده و مبتنی بر یادگیری جمعی استفاده می‌کنیم.

چکیده: تولید متن یکی از مسایل مهم در حوزه پردازش زبان طبیعی به حساب می‌آید. روش‌های پایه ارائه‌شده در این حوزه، دارای مشکلاتی نظیر ناهمخوانی داده در زمان آموزش و آزمون و همچنین تابع هدف نامناسب هستند. در چند سال اخیر پیشرفت‌های زیادی در حوزه تولید تصویر به وسیله شبکه‌های مولد مقابله‌ای انجام شده است. همین موضوع باعث شده که استفاده از شبکه‌های مولد مقابله‌ای در تولید متن نیز به تازگی مورد توجه قرار گیرد. اما به دلیل گسسته‌بودن جنس دنباله‌ها، این امر به سادگی میسر نبوده و برای حل آن نیاز به استفاده از راهکارهایی مثل یادگیری تقویتی و استفاده از تقریب وجود دارد. به علاوه ناپایداری شبکه‌های مولد مقابله‌ای باعث ایجاد چالش‌های جدید و بالارفتن پیچیدگی مسأله می‌شود.

در این پژوهش با رویکردی جدید که جمعی و مبتنی بر ایده شبکه‌های مولد مقابله‌ای است به ارائه روشی جمعی برای حل مسأله تولید متن می‌پردازیم. اساس روش پیشنهادی تخمین نسبت چگالی احتمال بوده و با این رویکرد روشی بدون مشکل در برابر گسستگی دنباله‌ها ارائه شده است. راهکار ارائه‌شده نسبت به روش‌های شبکه‌های مولد مقابله‌ای در حوزه دنباله، آموزشی پایدارتر دارد و همچنین مشکل آریبی مواجهه نیز در روش پیشنهادی وجود ندارد. آزمایش‌های انجام‌شده نشان‌دهنده برتری روش پیشنهادی در مقایسه با روش‌های پیشین بر روی مجموعه داده‌های معروف مربوط به تولید متن است.

کلیدواژه: تولید متن، مدل مولد، شبکه‌های GAN، یادگیری جمعی.

۱- مقدمه

تولید متن یکی از زمینه‌های مهم پردازش زبان طبیعی محسوب می‌شود که در چند سال اخیر بسیار مورد توجه قرار گرفته است. تولید زبان طبیعی در سیستم‌های مکالمه و پاسخ‌گویی خودکار، خلاصه‌سازی متن، ترجمه متن، تولید عنوان برای تصاویر و بسیاری از دیگر حوزه‌های مرتبط با متن کاربرد دارد.

روش‌های پایه تولید متن مبتنی بر تابع هدف بیشینه درست‌نمایی^۱ هستند و در آموزش مدل، به دنبال افزایش احتمالی هستند که مدل به داده‌های آموزش انتساب می‌دهد. در حالی که اگر به دنبال مدل‌هایی باشیم که نمونه‌های تولیدی آن در توزیع واقعی داده‌ها (که در دسترس نیست) احتمال بالایی بگیرند، رویکرد منطقی‌تری است. با این وجود راه حلی برای به کارگیری این تابع هدف وجود ندارد. در حالتی که ظرفیت مدل به اندازه کافی زیاد باشد با در نظر گرفتن تابع درست‌نمایی به عنوان تابع هدف می‌توان توزیع داده اصلی را یاد گرفت. ولی در حالتی که ظرفیت مدل در مقابل داده‌های آموزش کم است مدل نمی‌تواند توزیع

این مقاله در تاریخ ۹ تیر ماه ۱۳۹۸ دریافت و در تاریخ ۸ تیر ۱۳۹۸ بازنگری شد.

احسان منتهائی، دانشکده مهندسی کامپیوتر، دانشگاه صنعتی شریف، تهران، ایران، (email: ehsan.montahaei@gmail.com).

مهدیه سلیمانی باغشاه (نویسنده مسئول)، دانشکده مهندسی کامپیوتر، دانشگاه صنعتی شریف، تهران، ایران، (email: soleymani@sharif.edu).

1. Maximum Likelihood

2. Mean-Seeking

3. Generative Adversarial Networks

4. Generator

5. Discriminator

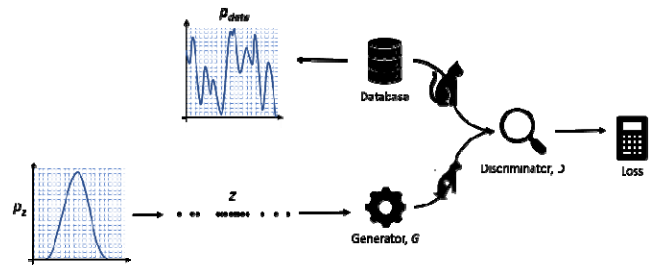
$$D_G^*(x) = \frac{P_{data}(x)}{P_{data}(x) + P_g(x)} \quad (۳)$$

که p_g نشان دهنده توزیع مولد است.

۳- کارهای پیشین

یکی از اولین و مهم‌ترین روش‌های موجود برای تولید متن شبکه‌های عصبی بازگردنده (RNNs) هستند که با هدف پیشینه‌کردن درست‌نمایی آموزش می‌بینند و با مشکل آریبی مواجهه^۲ که در روش پایه جبر معلم^۳ وجود دارد، روبه‌رو هستند. در واقع در این روش‌ها مشابه اکثر روش‌های تولید دنباله، مسأله ساده‌سازی می‌شود و به این شکل تبدیل می‌شود که با داشتن یک زیردنباله، توزیع احتمال عنصر بعدی دنباله مدل می‌شود. بنابراین اگر در زمان آموزش این زیردنباله‌ها فقط داده‌های واقعی باشند (که این حالت آموزش را اصطلاحاً جبر معلم می‌گویند) مشکل ناهماهنگی آموزش و آزمون پیش می‌آید، زیرا مدل فقط تصمیم‌گیری با داشتن زیردنباله‌های کاملاً صحیح را آموزش دیده ولی در زمان آزمون با زیردنباله‌های تولید خودش مواجه می‌شود، این مشکل آریبی مواجهه نامیده می‌شود [۱] و [۵]. برای جلوگیری از این مشکل و همین‌طور به منظور معرفی تابع هدف مناسب‌تر برای یادگیری یک مدل مولد متن، شبکه‌های مولد مقابله‌ای متعددی معرفی شدند. در آموزش شبکه‌های مولد مقابله‌ای در یک گام تمیزدهنده و در گام دیگر مولد آموزش می‌بینند. در این آموزش شبکه مولد با تابع هزینه‌ای آموزش می‌بیند که بر اساس شبکه تمیزدهنده ساخته شده است. به عبارتی می‌توان این گونه تفسیر کرد که تمیزدهنده با یادگرفتن ضعف‌های مولد نسبت به داده اصلی، به آموزش مولد کمک می‌کند تا به سمتی رود که این ضعف‌ها کمتر شود. شبکه‌های مولد مقابله‌ای برای آموزش مولد از گرادینان که به وسیله تمیزدهنده تولید می‌شود، استفاده می‌کنند. این موضوع در داده‌های گسسته که مشتق‌پذیری ندارند باعث مشکل انتقال گرادینان می‌شود. بخش عمده تلاش کارهای پیشین در رفع این مشکل بوده است.

اگرچه راهکارهای زیادی برای استفاده از یادگیری مقابله‌ای در حوزه داده‌های پیوسته پیشنهاد و استفاده شده است، ولی به دلیل مشکل انتقال گرادینان در داده‌های گسسته، مستقیماً امکان استفاده از این روش‌ها در حوزه داده‌های گسسته وجود ندارد [۳]. شبکه‌های مولد مقابله‌ای برای تولید متن را می‌توان به چهار دسته تقسیم کرد. هر یک از این چهار دسته راهکاری برای حل مشکل انتقال گرادینان ارائه می‌دهند. دسته اول با یک تقریب فضای گسسته مسأله را به صورت یک فضای پیوسته درمی‌آورند [۶]. این دسته از روش‌ها با کمک تکنیک Gumbel Softmax [۷] و [۸] تقریب را انجام می‌دهند. دسته دوم با کار در فضای ویژگی این مشکل را حل کرده‌اند [۹] و [۱۰]. یکی از مهم‌ترین روش‌های این دسته روش TextGAN [۱۰] است که به وسیله شبکه تمیزدهنده، ویژگی‌های مناسبی از دنباله به دست می‌آورد و شبکه مولد در این فضا دو توزیع اصلی و مولد را به هم نزدیک می‌کند. سومین دسته که بیشتر روش‌های پیشین را دربرمی‌گیرد، مسأله آموزش مولد را به یک مسأله یادگیری تقویتی تبدیل کرده‌اند و بدون مشکل انتقال گرادینان، تکنیک‌های این حوزه را برای حل مسأله به کار بسته‌اند [۴] و [۱۱] تا [۱۴]. در دسته آخر روش‌هایی وجود دارد که با تغییر تعریف صورت مسأله،



شکل ۱: نمای کلی شبکه‌های مولد مقابله‌ای.

۲- پیش‌زمینه: شبکه‌های مولد مقابله‌ای

در این بخش شبکه‌های مولد مقابله‌ای را مختصراً معرفی می‌کنیم. اساس کار شبکه‌های مولد مقابله‌ای [۲] بازی بین دو شبکه می‌باشد. شبکه اول مولد است که نمونه تولید می‌کند و شبکه دوم یک دسته‌بند احتمالاتی دو دسته‌ای است که بر روی نمونه‌های تولیدشده و واقعی قضاوت کرده و با این قضاوت شبکه مولد را به سمت بهبود راهنمایی می‌کند. به صورت دقیق‌تر، شبکه مولد به سمتی می‌رود که دسته‌بند را به خطا بیندازد و دسته‌بند هم به سمتی می‌رود که دسته‌بندی درست انجام دهد. یک حالت تعادل این بازی زمانی است که مولد نمونه‌های مشابه نمونه‌های واقعی تولید کند و دسته‌بند هم به داده‌های واقعی و هم برای داده‌های تولیدشده احتمال ۰/۵ نسبت دهد. زیرا در حالتی که دو دسته داده دارای توزیع یکسان هستند، تشخیص درست توسط دسته‌بند، دادن احتمال ۰/۵ به هر دسته به ازای هر کدام از داده‌ها است.

مدل دسته‌بند که به نام تمیزدهنده شناخته می‌شود، یک شبکه دسته‌بند دودسته‌ای عادی است. تابع هزینه این روش به صورت زیر است

$$\min_G \max_D V(D, G) = E_{x \sim P_{data}} \log D(x) + E_{z \sim P_z} \log(1 - D(G(z))) \quad (۱)$$

در رابطه بالا تابع هدف $V(D, G)$ ، منفی تابع هزینه دسته‌بندی بین مجموعه داده $\{x | x \sim P_{data}\}$ به عنوان دسته با برچسب یک و مجموعه داده $\{G(z) | z \sim P_z\}$ به عنوان دسته با برچسب صفر است که P_z نشان‌دهنده توزیع فضای نهان است. این تابع هدف، توسط D که تمیزدهنده است، پیشینه می‌شود یعنی تمیزدهنده به دنبال آن است که دسته‌بندی درست را انجام دهد و از سمت دیگر تابع هدف نسبت به G که مولد است کمینه می‌شود. بنابراین هدف آن است که نمونه‌های تولیدی مولد طوری باشد که تمیزدهنده به اشتباه بیفتد. در شکل ۱ نمای از نحوه عملکرد GAN آمده است.

در عمل تابع هزینه ۱ به طور مستقیم قابل استفاده نیست و روش حلی که برای آن ارائه شده آموزش گام‌به‌گام شبکه مولد و تمیزدهنده است، به این صورت که در یک مرحله مدل مولد و در مرحله دیگر مدل تمیزدهنده آموزش می‌بینند. با تکرار این مراحل، آموزش انجام می‌شود. مطابق راه حل گفته‌شده تابع هزینه دو شبکه به صورت زیر درمی‌آید

$$\begin{aligned} \mathcal{L}_D &= -E_{x \sim P_{data}} \log D_\phi(x) - E_{z \sim P_z} \log(1 - D_\phi(G_\theta(z))) \\ \mathcal{L}_G &= E_{z \sim P_z} \log(1 - D_\phi(G_\theta(z))) \end{aligned} \quad (۲)$$

نکته‌ای که در رابطه بالا وجود دارد تابع هزینه مولد است. زمانی که شبکه مولد به روز رسانی می‌شود، گرادینان \mathcal{L}_G نسبت به θ لازم است و برای معتبربودن این گرادینان باید نسبت به x مشتق‌پذیر باشد.

برای یک مولد ثابت، تمیزدهنده بهینه به صورت زیر درمی‌آید [۲]

1. Recurrent Neural Networks
2. Exposure Bias
3. Teacher Forcing

تمیزدهنده از شبکه‌ای رتبه‌بند^۷ استفاده می‌کند. این موضوع باعث کمک بیشتر به شبکه مولد می‌شود. روال آموزش این روش به این صورت است که رتبه‌بند در یک گام آموزش داده شده و به سمتی سوق داده می‌شود که رتبه کمتری به داده مصنوعی نسبت دهد. در گام دیگر مولد سعی در به اشتباه انداختن شبکه رتبه‌بند دارد به طوری که دنباله‌های تولیدشده رتبه بهتری نسبت به دنباله‌های واقعی بگیرند. به نوعی می‌توان گفت این نحوه آموزش نسبت به روش SeqGAN باعث انتقال اطلاعات بیشتری به مولد برای آموزش می‌شود.

همان گونه که گفته شد، روش‌هایی مثل RankGAN و SeqGAN به وسیله یادگیری تقویتی درصدد حل مشکل انتقال گرادیان هستند و برای آموزش شبکه مولد از خروجی عددی تمیزدهنده به عنوان پاداش استفاده می‌کنند. یکی از مشکلات این رویکرد کم‌بودن میزان اطلاعاتی است که از تمیزدهنده به مولد می‌رسد، به طوری که برای یک دنباله کوتاه یا طولانی فقط یک عدد برای آموزش مولد وجود دارد. این شرایط مقایسه شود با شبکه‌های مولد مقابله‌ای بر روی داده پیوسته‌ای مثل تصویر که گرادیان نسبت به تک‌تک پیکسل‌های تصویر به مولد می‌رسد. از سمت دیگر، در مسأله یادگیری تقویتی تعریف‌شده، محیط به صورت جعبه‌سیاه^۸ نیست و محیط مسأله (که در واقع همان تمیزدهنده است) شناخته شده است؛ بنابراین می‌توان اطلاعات بیشتری به جای فقط یک عدد از آن استخراج کرد [۱۳]. روش LeakGAN که در [۱۳] معرفی شده است با استفاده بیشتر از تمیزدهنده، سعی در بهبود آموزش مولد به خصوص برای تولید جملات طولانی‌تر دارد. برای این منظور از یک روش سلسله‌مراتبی^۹ به نام شبکه‌های فتودالی^{۱۰} [۱۸] استفاده کرده است. این شبکه‌ها در حوزه یادگیری تقویتی برای محیط‌هایی با پاداش تأخیردار^{۱۱} استفاده می‌شوند. روش LeakGAN برای استفاده بیشتر از تمیزدهنده، از شبکه‌های فتودالی به عنوان مولد استفاده می‌کند. یعنی شبکه مدیر^{۱۲}، ویژگی‌های کلی دنباله‌ای را که مولد تولید می‌کند، مشخص کرده و شبکه کارگر^{۱۳} تولید کلمات را بر این اساس انجام می‌دهد. بقیه موارد مشابه دیگر شبکه‌های مبتنی بر یادگیری مقابله‌ای بوده که در یک گام تمیزدهنده آموزش داده می‌شود و در گام دیگر مولد. در این روش فضای ویژگی‌ای که برای شبکه‌های فتودالی لازم است، بر حسب شبکه تمیزدهنده به دست می‌آید. یک شبکه عصبی پیچشی^{۱۴} (CNNs) به عنوان تمیزدهنده استفاده می‌شود و ویژگی‌های تولیدشده توسط این شبکه به عنوان فضای نهان در نظر گرفته می‌شود. به این ترتیب از وضعیت داخلی تمیزدهنده در آموزش استفاده می‌شود. یعنی مدیر پیش‌بینی می‌کند که تغییر در فضای ویژگی‌های تمیزدهنده در چه سمتی به تولید دنباله‌های واقعی‌تر منجر می‌شود و کارگر با کمک مدیر، دنباله‌هایی تولید می‌کند که این امر محقق شود. شبکه کارگر و مدیر هر کدام یک شبکه LSTM هستند.

روش معرفی‌شده در [۱۴] که MaliGAN نام دارد، با تعریف تابع هدفی جدید به نحوه آموزش شبیه به روش SeqGAN می‌رسد، ولی با

مشکل انتقال گرادیان را حل می‌کنند و به جای دنباله گسسته یک دنباله از توزیع‌های دسته‌ای تولید می‌کنند [۱۵] تا [۱۷].

از بین روش‌های موجود مبتنی بر شبکه‌های مولد مقابله‌ای روش‌های دسته سوم بهترین عملکرد را از خود نشان داده‌اند. روش‌های مبتنی بر یادگیری تقویتی، با در نظر گرفتن مولد به عنوان عامل^۱ مسأله یادگیری تقویتی و تعریف پاداش بر اساس خروجی تمیزدهنده (میزان به اشتباه افتادن تمیزدهنده)، مسأله را حل می‌کنند. به طور دقیق‌تر تولید دنباله را می‌توان یک مسأله یادگیری تقویتی دید، به این صورت که در هر مرحله، وضعیت^۲ همان دنباله تولیدشده تا به آن لحظه است و عملی^۳ که عامل می‌تواند انجام دهد، انتخاب عنصر بعدی دنباله است. محیط توصیف‌شده یک محیط قطعی است و با انجام هر عمل، وضعیت جدید به صورتی قطعی مشخص می‌شود؛ زیرا با انجام عمل، دنباله جدید که با اضافه شدن کلمه انتخاب‌شده به دست آمده، نشان‌دهنده وضعیت جدید است. عامل به این صورت مدل می‌شود که یک سیاست^۴ وجود دارد که برای هر وضعیت توزیع احتمالی روی عمل‌های ممکن را مشخص می‌کند و برای انتخاب عمل در هر وضعیت از این توزیع نمونه‌گیری می‌شود. در مسأله یادگیری تقویتی به دنبال یافتن سیاستی هستیم که امید پاداش^۵ دریافتی را بیشینه کند. معادله زیر نشان‌دهنده تابع هزینه است به طوری که $R(x)$ پاداش نسبت داده شده به دنباله x و π_θ بیانگر سیاست است

$$\theta^* = \arg \max_{\theta} E[R(x)|\pi_{\theta}] \quad (4)$$

لازم به ذکر است که فقط برای دنباله‌های کامل پاداش وجود دارد. یکی از روش‌های ساده و پرستفاده حل مسأله گفته‌شده، گرادیان سیاست^۶ است. در ادامه روش‌های مقابله‌ای مبتنی بر یادگیری تقویتی با جزئیات بیشتر معرفی می‌شوند.

روش SeqGAN که در [۴] معرفی شده است از اولین راهکارهای استفاده از یادگیری مقابله‌ای در حوزه تولید دنباله بوده است. این روش مسأله تولید دنباله را با در نظر گرفتن مسأله به عنوان یک مسأله یادگیری تقویتی حل می‌کند. در این مسأله پاداش، خروجی شبکه تمیزدهنده است. خروجی شبکه تمیزدهنده، احتمالی است که این شبکه به واقعی بودن دنباله ورودی می‌دهد. این خروجی عددی بین صفر و یک است که هرچه به یک نزدیک‌تر باشد داده از دید تمیزدهنده واقعی‌تر و هرچه به صفر نزدیک باشد غیر واقعی‌تر است. این روش برای حل مسأله یادگیری تقویتی تعریف‌شده، از راهکار گرادیان سیاست استفاده می‌کند و با استفاده از پاداش دریافت‌شده، گرادیانی را برای شبکه مولد تخمین می‌زند که با این گرادیان تخمین زده شده، شبکه مولد آموزش می‌بیند. با ایده گرفتن از شبکه‌های مولد مقابله‌ای، در روش SeqGAN دو شبکه مولد و تمیزدهنده وجود دارد و آموزش به این صورت است که در یک گام تمیزدهنده بر روی داده‌های واقعی و داده‌های تولیدشده آموزش می‌بیند و در گام دیگر با کمک دسته‌بند آموزش‌دیده، شبکه مولد آموزش داده می‌شود.

روش یادگیر مقابله‌ای که تشریح شد محدود به دسته‌بندی دودسته‌ای به عنوان تمیزدهنده هست. روش RankGAN [۱۲] به جای استفاده از

7. Ranker
8. Black Box
9. Hierarchical
10. Feudal Networks
11. Delayed Reward
12. Manager
13. Worker
14. Convolutional Neural Networks

1. Agent
2. State
3. Action
4. Policy
5. Reward
6. Policy Gradient

مولد استفاده می‌شود تا به کمک آنها، توزیع جدید به نحوی به دست بیاید که تمیزدهنده آن را به عنوان توزیع داده واقعی در نظر گیرد، این روال به صورت تکرار شونده انجام می‌شود. روش پیشنهادی با کمک گرفتن از ساختار داشتن دنباله و محدود بودن کلمات ممکن، موفق به ایجاد توزیع جدید می‌شود، بنابراین می‌توان گفت که مشکلات گسستگی دنباله در اینجا موجب مزیت شده است. همچنین رویکردی که در روش پیشنهادی برای استفاده از تمیزدهنده جهت آموزش مولد به کار گرفته می‌شود، مشکل انتقال گرادیان را هم رفع می‌کند. چون عملاً برای به روز رسانی مولد از یک رابطه فرم بسته استفاده می‌شود که در آن نیازی به انتقال گرادیان نیست. در عمل در این روش از توزیع مولد اولیه و همه تمیزدهنده‌های پیداشده در گام‌های مختلف به صورت جمعی استفاده می‌شود تا مولد جدید مربوط به آن مرحله پیدا شود.

۴-۱-۱ پیش‌نیاز

در این بخش، ابتدا درباره نحوه مدل کردن توزیع دنباله توسط مولد توضیحاتی داده می‌شود. سپس در ادامه کلیاتی درباره تخمین نسبت چگالی دو توزیع، مستقل از بحث دنباله گفته می‌شود و راهکاری برای آن با ذکر برخی از جزئیات تشریح می‌شود.

۴-۱-۱-۱ مدل کردن دنباله

فرض کنید توزیع مدل مولد را با توزیع Q_θ نشان می‌دهیم، مشابه روش‌های قبل برای ساده کردن توزیع، آن را به اجزای ساده‌تر می‌شکنیم

$$q(x; \theta) = q(x_1; \theta) \prod_{l=2}^L q(x_l | x_{1:l-1}; \theta) \quad (۸)$$

بنابراین برای آموزش مدل کافی است که توزیع‌های شرطی $q(x_l | x_{1:l-1}; \theta)$ را به دست آوریم. برای نمونه‌گیری از توزیع Q_θ می‌توان از توزیع‌های شرطی به صورت نیایی^۵ نمونه‌گیری کرد. یعنی ابتدا ابتدا x_1 از توزیع $q(x_1)$ نمونه گرفته می‌شود، سپس با مشخص شدن مقدار x_1 از توزیع شرطی $q(x_2 | x_1)$ کلمه دوم یعنی x_2 نمونه‌گیری می‌شود و به همین صورت تا L نمونه‌گیری انجام شده و در نهایت دنباله‌ای به طول L از توزیع Q_θ به دست می‌آید.

۴-۱-۲ تخمین نسبت چگالی

در این قسمت بیان می‌شود که چگونه توسط آموزش دسته‌بندی دودسته‌ای می‌توان تخمینی از نسبت چگالی دو توزیع به دست آورد. لازم به ذکر است که در ادامه منظور از تمیزدهنده، یک دسته‌بند دودسته‌ای است. با توجه به مطالب بخش ۲ برای هر مولد q با فرض ظرفیت کافی برای مدل تمیزدهنده، تمیزدهنده بهینه می‌تواند طبق رابطه $D^*(x) = p(x)/(p(x)+q(x))$ به دست آید که $p(x)$ و $q(x)$ به ترتیب نشان‌دهنده تابع چگالی توزیع مطلوب و توزیع مولد است [۲]. به این ترتیب راه حلی برای تخمین نسبت $p(x)/q(x) = D^*(x)/(1-D^*(x))$ داریم. در روش پیشنهادی، از این نسبت تخمین زده شده برای پیدا کردن مدل مولد استفاده می‌شود.

۴-۲ راهکار پیشنهادی

روش پیشنهادی دو گام دارد: مرحله آموزش تمیزدهنده که به اختصار آن را گام «یادگیری تمیزدهنده» و گام به روز رسانی توزیع Q که به اختصار آن را گام «به روز رسانی مولد» می‌نامیم. این دو گام به صورت

تفاوت‌هایی که دارد آموزش آن پایداری بیشتری پیدا می‌کند. همچنین این روش در مقایسه با روش پایه جبر معلم مقاومت بیشتری نسبت به مشکل بیش‌برازش^۱ دارد [۱۴]. تابع هدف تمیزدهنده، مشابه شبکه‌های مولد مقابله‌ای، تابع هزینه دسته‌بند عادی است. ولی تابع هدفی که برای مولد استفاده می‌شود برابر $D_{KL}(\tilde{P}||Q)$ است که \tilde{P} نشان‌دهنده یک تخمین از توزیع واقعی است. برای یافتن توزیع تخمینی \tilde{P} از تمیزدهنده بهینه استفاده می‌شود

$$D^*(x) = \frac{p_{data}(x)}{p_{data}(x)+q(x)} \Rightarrow p_{data}(x) = \frac{D^*(x)}{1-D^*(x)} q(x) \quad (۵)$$

طبق این رابطه، \tilde{P} به عنوان تقریبی از توزیع واقعی (p_{data}) به کمک تمیزدهنده D و چگالی توزیع فعلی مولد که با $q(x)$ مشخص شده است به صورت زیر به دست می‌آید

$$\tilde{p}(x) = \frac{D(x)}{1-D(x)} q(x) \quad (۶)$$

برای آموزش مولد، بعد از آموزش تمیزدهنده از شبکه مولد فعلی رونوشت^۲ رونوشت^۳ گرفته می‌شود. تابع چگالی و توزیع رونویسی شده به ترتیب با $q'(x)$ و Q' نشان داده می‌شود. سپس شبکه مولد با تابع هدف $D_{KL}(\tilde{P}||Q)$ آموزش می‌بیند و $\tilde{p}(x)$ بر اساس Q' با کمک (۶) به دست می‌آید. بنابراین تابع هزینه مولد به صورت زیر می‌شود

$$\begin{aligned} \mathcal{L}_G &= D_{KL}(\tilde{P}||Q_\theta) \\ \tilde{p}(x) &= \frac{1}{Z(\theta)} \frac{D(x)}{1-D(x)} q'(x) \end{aligned} \quad (۷)$$

که در رابطه گفته شده برای اطمینان از توزیع بودن \tilde{P} ضریب نرمال سازی در نظر گرفته شده است. روش MaliGAN برای استفاده از تابع هدف بیان شده، با کمک نمونه‌گیری بر اساس اهمیت^۴ به جای نمونه‌گیری از توزیع \tilde{P} ، نمونه‌گیری از مدل مولد را انجام می‌دهد. لازم به ذکر است که روش MaliGAN برای تولید متن ارائه شده و نسخه کلی‌تر آن که برای تولید تصاویر نیز مورد استفاده قرار گرفته در [۱۹] معرفی شده است.

در مورد زبان فارسی مطالعات بسیار محدودی در زمینه تولید متن انجام شده است [۲۰] و [۲۱]. این مطالعات با رویکرد پیشینه درست‌نمایی و عمدتاً با استفاده از شبکه‌های RNN و LSTM مربوط می‌شود و استفاده از شبکه‌های مولد برای داده‌های فارسی مورد بررسی قرار نگرفته است.

۴- روش پیشنهادی

در این بخش روش پیشنهادی که یک روش مولد تکرار شونده^۴ و جمعی برای تولید متن است معرفی خواهد شد. روش پیشنهادی برخلاف روش‌های پیشین، از مولدهای شکل گرفته در جریان آموزش به صورت جمعی برای تشکیل مدل مولد نهایی استفاده می‌کند. همچنین برخلاف روش‌های مقابله‌ای معمول به ازای تمیزدهنده به دست آمده در یک گام، شبکه مولد به طور کامل بهینه می‌شود. روش پیشنهادی به این صورت است که در هر گام تمیزدهنده‌ای بین داده‌های تولید شده توسط مدل مولد و داده‌های واقعی آموزش می‌بیند. سپس از آخرین تمیزدهنده و آخرین

1. Overfitting
2. Copy
3. Importance Sampling
4. Iterative

$$q^{new}(x_i) \leftarrow r_\theta(x_i)q^{old}(x_i) \quad (12)$$

$$q^{new}(x_l|x_{1:l-1}) \leftarrow r_\theta(x_l)q^{old}(x_l|x_{1:l-1}), \quad 2 \leq l \leq L$$

با فرض بهینه‌بودن تخمین نسبت چگالی، توزیع جدید به صورت زیر محاسبه می‌شود

$$q^{new}(x_i) = r(x_i)q^{old}(x_i) = \frac{p(x_i)}{q^{old}(x_i)}q^{old}(x_i) = p(x_i)$$

$$q^{new}(x_l|x_{1:l-1}) = r(x_l)q^{old}(x_l|x_{1:l-1}) = \frac{p(x_l|x_{1:l-1})}{q^{old}(x_l|x_{1:l-1})}q^{old}(x_l|x_{1:l-1}) = p(x_l|x_{1:l-1}), \quad 2 \leq l \leq L$$

که نتیجه نشان می‌دهد در صورت بهینه‌بودن r_θ ، آموزش در یک گام تمام می‌شود و به جواب درست می‌رسد. به عبارت دیگر از روی مدل مولد مرحله قبل با کمک تمیزدهنده بهینه به مدل مولد بهینه یا همان $p(x)$ می‌رسیم. در عمل بهینه‌نبودن تمیزدهنده مورد استفاده سبب می‌شود که پیداشدن توزیع مطلوب در یک گام اتفاق نیفتد و مجبور به استفاده از یک الگوریتم تکرارشونده خواهیم شد که در هر گام آن D_θ و Q جدیدی داریم. به عبارت دیگر با داشتن مولد مرحله قبل و همچنین تمیزدهنده D'_θ (که با توجه به داده واقعی و مدل مولد مرحله قبل به دست آمده) توزیع Q^t با استفاده از (۶) به صورت زیر به دست می‌آید

$$q^t(x) = \frac{D'_\theta(x)}{1 - D'_\theta(x)} q^{t-1}(x) \quad (14)$$

که با جایگذاری توزیع $q^{t-1}(x)$ و تکرار این روند تا رسیدن به $q^t(x)$ در نهایت به رابطه زیر می‌رسیم


$$q^t(x) = \prod_{i=1}^t \frac{D'_\theta(x)}{1 - D'_\theta(x)} q^i(x) \quad (15)$$

به این ترتیب با شروع از یک توزیع مولد اولیه و نگاه داشتن تمیزدهنده‌های مراحل مختلف می‌توان با یک مدل جمعی^۱ که از تمیزدهنده‌های تمام مراحل قبل استفاده می‌کند طبق رابطه بالا مولد جدید را به دست آورد. نمای کلی آموزش در روش پیشنهادی در شکل ۲ مشخص شده است.

۳-۴ جزئیات روش

برای مدل کردن تمیزدهنده بر روی دنباله‌های با تمام طول‌های ممکن از یک شبکه بازگردنده LSTM استفاده می‌شود، به این صورت که ورودی سلول اول کلمه‌ای به عنوان کلمه شروع است. کلمه شروع یک کلمه تعریف شده و ثابت است که نشان‌دهنده شروع دنباله است. سلول دوم x_1 را ورودی می‌گیرد، ورودی سلول سوم x_2 است و به همین صورت تا کلمه L ام ورودی آخرین سلول می‌شود. کلمات قبل از ورود به شبکه، در برداری با اندازه E تعبیه می‌شوند. بردارهای کلمات با v_w نمایش داده می‌شوند و تعداد آنها به اندازه مجموعه واژگان است و این بردارها معادل تعبیه کلمات مجموعه واژگان هستند. V نشان‌دهنده تعداد واژگان است و هر یک از واژه‌های ممکن با عددی بین ۱ تا V مشخص می‌شوند. خروجی i ام شبکه بازگردنده را با h_i نشان می‌دهیم که تابعی از کلمات x_1 تا x_{i-1} است.

بنابراین تمیزدهنده برای l های مختلف به صورت زیر مدل می‌شود



شکل ۲: نمای کلی روش پیشنهادی (گام یادگیری تمیزدهنده با A و گام به روز رسانی مولد با B مشخص شده است).

تکرارشونده انجام می‌شود. در ادامه این دو گام بیان می‌شود و سپس در بخش جزئیات روش، نحوه مدل کردن و تکنیک‌های مورد استفاده شرح داده می‌شود.

۴-۲-۱ گام یادگیری تمیزدهنده

همان طور که گفته شد این روش به صورت تکرارشونده کار می‌کند، زمانی که گام یادگیری تمیزدهنده انجام می‌شود توزیع مدل فعلی را Q^t می‌نامیم.

طبق روش گفته شده در بخش ۴-۱-۲ می‌توان نسبتی بین توزیع Q^t و P_{data} تخمین زد، زیرا نمونه‌هایی از توزیع واقعی در اختیار داریم و به علاوه توانایی نمونه‌گیری از Q^t نیز وجود دارد. در گام یادگیری تمیزدهنده، با نمونه‌های دو توزیع P_{data} و Q^t ، تمیزدهنده را بین این دو مجموعه آموزش می‌دهیم و با کمک آن نسبت چگالی را تخمین می‌زنیم. بنابراین به شبکه‌ای برای مدل کردن تمیزدهنده نیاز است که برای هر طول ممکن از دنباله‌ها، به دنباله ورودی عددی بین صفر و یک نسبت دهد. برای آموزش تمیزدهنده مربوط به دنباله‌های با طول l ، امید تابع هزینه آموزش تمیزدهنده به صورت زیر به دست می‌آید

$$\mathcal{L}(\theta) = -E_{x_{1:l} \sim P_{data}} \log D_\theta(x_{1:l}) - E_{x_{1:l} \sim Q^{old}} \log(1 - D_\theta(x_{1:l})) \quad (9)$$

و رابطه تخمین نسبت چگالی با استفاده از D_θ حاصل بهینه‌سازی رابطه بالا به صورت زیر پیدا می‌شود

$$r_\theta(x_{1:l}) = \frac{D_\theta(x_{1:l})}{1 - D_\theta(x_{1:l})} \quad (10)$$

در رابطه بالا، خروجی تمیزدهنده مربوط به دنباله‌های با طول l با $D_\theta(x_{1:l})$ نشان داده شده است. همچنین $r_\theta(x_{1:l})$ به مفهوم نسبت چگالی تخمینی است

$$r_\theta(x_{1:l}) \approx \frac{p(x_l|x_{1:l-1})}{q^{old}(x_l|x_{1:l-1})} \quad (11)$$

که $p(x_l|x_{1:l-1})$ و $q^{old}(x_l|x_{1:l-1})$ به ترتیب چگالی توزیع شرطی واقعی و توزیع شرطی فعلی مدل برای دنباله‌های به طول l است.

۴-۲-۲ گام به روز رسانی مولد

در بخش قبل نحوه محاسبه $r_\theta(x_{1:l})$ به عنوان تخمینی از نسبت چگالی گفته شد. در گام به روز رسانی مولد، چگالی توزیع Q با کمک این نسبت بهبود پیدا می‌کند و مقدار جدید آن بر حسب مقدار قبلی و $r_\theta(x_{1:l})$ به دست می‌آید. نحوه به روز رسانی توزیع به صورت زیر است

۴-۴ تحلیل روش پیشنهادی

با استفاده از قضایای مطرح شده در [۲۲] می‌توان نشان داد که بعد از گام یادگیری تمیزدهنده، تخمینی از نسبت چگالی توزیع احتمال به دست می‌آید. در مرحله به روز رسانی مولد اگر فرض شود در هر یک از گام‌ها نسبت چگالی تخمین زده شده بهینه باشد، توزیع به دست آمده در گام به‌روزرسانی مولد، توزیع مطلوب و برابر توزیع اصلی است. این موضوع در (۱۳) نشان داده شده است. از آنجا که نسبت چگالی تخمین زده‌شده لزوماً بهینه نیست از رویکرد تکرار شونده برای پیدا کردن مولد استفاده می‌شود.

۵-۱ آزمایش‌ها

در این بخش برای بررسی کارایی روش پیشنهادی، این روش را با چند روش برتر حوزه تولید متن مقایسه می‌کنیم. به علاوه نمونه‌هایی از متون تولیدی روش بر روی متن فارسی گزارش شده است. در ادامه مجموعه داده مورد استفاده، معیار ارزیابی و پیکربندی روش‌ها تشریح شده است.

۵-۱-۱ مجموعه داده

برای ارزیابی از پراستفاده‌ترین مجموعه داده‌ها در حوزه تولید متن استفاده شده که این مجموعه داده‌ها به شرح زیر هستند:

- مجموعه داده COCO Captions: این مجموعه داده در اصل مربوط به ۶۰۰ هزار عنوان مربوط به تصاویر است. جملات با طول ۵ تا ۲۵ کلمه جدا شده است. سپس از این بین ۴۰ هزار جمله برای آموزش، ۲۰ هزار جمله برای اعتبارسنجی و ۲۰ هزار جمله برای آزمون انتخاب شده است. مجموعه داده حاصل شامل ۵۳۲۸ کلمه متفاوت است.
- مجموعه داده EMNLP۲۰۱۷ WMT News: این مجموعه داده شامل ۲۰ میلیون جمله است. از این جملات ۵۰۰ هزار جمله به صورت تصادفی انتخاب شده و جملات با طول بین ۲۰ تا ۴۰ کلمه جدا شده است. از این بین ۴۰ هزار جمله برای آموزش، ۲۰ هزار جمله برای اعتبارسنجی و ۲۰ هزار جمله برای آزمون انتخاب شده است. مجموعه داده حاصل شامل ۶۱۴۸ کلمه متفاوت است.
- مجموعه داده Chinese Poems: این مجموعه داده شامل ۱۲۷۹۸ شعر چهار خطی چینی است که توسط [۲۳] معرفی شده است. برای ساخت مجموعه آموزش ۱۰۰۲۸ شعر، برای اعتبارسنجی ۷۷۰ شعر و برای آزمون ۲۰۰۰ شعر به صورت تصادفی انتخاب شده است.

۵-۲ معیار ارزیابی

معیار مورد استفاده BLEU [۲۴] است که کیفیت جملات تولیدی را بررسی می‌کند. این معیار مبتنی بر n -گرام بوده و پراستفاده‌ترین معیار برای مقایسه نتایج است که در روش‌های مبتنی بر شبکه‌های مولد مقابله‌ای استفاده شده است. این معیار شباهت n -گرام‌های نمونه‌های تولیدی را نسبت به n -گرام‌های داده آزمون، ارزیابی می‌کند و بیشتر بودن آن به معنی بهتر بودن مدل است.

این معیار در ابتدا برای سنجش در مسأله ترجمه معرفی شده است به این صورت که به ازای یک جمله، مجموعه‌ای از ترجمه‌های درست به عنوان مجموعه مرجع وجود دارد. میزان شباهت n -گرام‌های جمله، با مجموعه مرجع اساس این معیار است. استفاده این معیار در زمینه تولید متن به این صورت است که کل جملات موجود در مجموعه آزمون به عنوان مجموعه مرجع معیار BLEU در نظر گرفته می‌شود و امتیاز هر یک از جملات تولیدشده به دست می‌آید. میانگین این امتیازها به ازای

$$D(x_{v:l-1}, x_l = w) = \text{Softmax}(F_w(x_{v:l-1}))|_w, 1 \leq w \leq V \quad (16)$$

$$F_w(x_{v:l-1}) = v_w \cdot h_{l-1}(x_{v:l-1})$$

لازم به ذکر است که v_w ها برای تمام مقادیر l ، مشترک هستند. از آنجا که تعداد کلمات محدود است، بر روی کلمات Softmax اعمال می‌شود تا در هنگام آموزش احتمال همه کلمات با یکدیگر تنظیم شود. برای تمیزدهنده مربوط به همه طول‌ها یک شبکه بازگردنده وجود دارد. در نتیجه تابع هزینه نهایی که آن را کمینه می‌کنیم به صورت زیر می‌شود

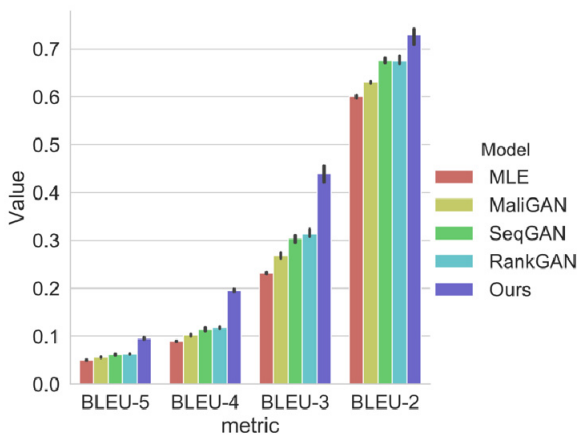
$$\begin{aligned} \mathcal{L}(\theta) = & -\sum_{l=1}^L E_{x_{v:l} \sim P_{data}} \log D_{\theta}(x_{v:l}) + \\ & E_{x_{v:l} \sim Q} \log(1 - D_{\theta}(x_{v:l})) = \\ & -E_{x_{v:l} \sim P_{data}} \left[\sum_{l=1}^L \log D_{\theta}(x_{v:l}) \right] - \\ & E_{x_{v:l} \sim Q} \left[\sum_{l=1}^L \log(1 - D_{\theta}(x_{v:l})) \right] \end{aligned} \quad (17)$$

برای کمینه‌کردن تابع هزینه (۱۷)، امیدها توسط روش مونت کارلو با نمونه‌های که داریم تخمین زده می‌شود. نمونه‌ها از توزیع P_{data} همان داده‌های آموزش است که در اختیار است. برای نمونه‌گیری از Q^{old} همان طور که در بخش ۴-۱-۱ تشریح شد از نمونه‌گیری نیایی استفاده می‌شود. تفسیری که از شبکه می‌توان داشت به این صورت است که تمیزدهنده می‌خواهد تشخیص دهد که اگر w به عنوان آخرین کلمه دنباله $x_{v:l}$ قرار بگیرد، دنباله حاصل چه میزان به دنباله واقعی نزدیک است. بنابراین لایه نهان به سمتی می‌رود که نمایش یاد گرفته شده برای $x_{v:l-1}$ در لایه نهان بتواند کلمه بعدی (یعنی w) را پیش‌بینی کند. بنابراین به طور صریح^۲ در اختیار داریم که انتخاب کلمه آخر از بین کلمات مختلف واژه‌نامه چه تأثیری بر روی واقعی به نظر رسیدن جمله دارد و به واسطه گسسته‌بودن مقادیر، با یادگیری تمیزدهنده عملاً توزیع را روی انتخاب آخرین کلمه برای واقعی به نظر رسیدن یافته‌ایم.


لازم به ذکر است که در هر مرحله از به روز رسانی، یک تمیزدهنده جدید وجود دارد. به همین منظور، برای نمادگذاری شماره مرحله از بالانویس استفاده شده است. برای مثال $F_m^w(x_{v:l-1})$ به معنی امتیاز تمیزدهنده m ام قبل از اعمال تابع خروجی بر روی دنباله ورودی $x_1 x_2 \dots x_{l-1} w$ است. همچنین $Q^{(m)}$ نشان‌دهنده توزیع به دست آمده بعد از گام به روز رسانی مولد به وسیله تمیزدهنده m ام است. روش آموزش به این صورت است که توزیع $Q^{(1)}$ اولیه، یک توزیع یکنواخت انتخاب می‌شود. سپس تمیزدهنده بر روی نمونه‌های اصلی و $Q^{(1)}$ آموزش داده می‌شود و نسبت چگالی تخمین زده می‌شود. به وسیله این نسبت، چگالی جدید $Q^{(1)}$ ساخته می‌شود و این روال ادامه پیدا می‌کند.

به این ترتیب برخلاف روش‌های مبتنی بر شبکه‌های مولد مقابله‌ای موجود که هر دو مدل تمیزدهنده و مولد را با استفاده از تکنیک‌های مبتنی بر گرادینان آموزش می‌دهند، در اینجا برای آموزش مولد نیازی به گرادینان تمیزدهنده نداریم و مولد با استفاده از یک فرم بسته بر حسب تمیزدهنده آموزش دیده و مولد قبلی، محاسبه می‌شود. به این ترتیب با چالش روش‌های پیشین مبتنی بر شبکه‌های مولد مقابله‌ای برای تولید دنباله‌های گسسته که در انتقال گرادینان تمیزدهنده به مولد دچار مشکل می‌شدند روبه‌رو نیستیم.

1. Share
2. Explicit



شکل ۵: نتایج روش‌های مختلف بر حسب BLEU-۲ تا BLEU-۵ همراه میزان انحراف معیار بر روی مجموعه داده Chinese Poems.



شکل ۳: نتایج روش‌های مختلف بر حسب BLEU-۲ تا BLEU-۵ همراه میزان انحراف معیار بر روی مجموعه داده COCO Captions.


اصلی است. در حین آموزش، هر پنج اپیک^۲ معیار BLEU بر روی مجموعه اعتبارسنجی بر حسب ۵۰۰۰ نمونه تولیدشده از مدل محاسبه می‌شود. در نهایت حالتی که مدل بهترین امتیاز را دارد به عنوان مدل نهایی در نظر گرفته می‌شود.

از آنجا که روش پیشنهادی به صورت جمعی است، برای عادلانه‌بودن مقایسه، شبکه روش پیشنهادی شامل چهار شبکه در نظر گرفته شده است که هر کدام اندازه لایه مخفی و فضای ویژگی ورودی ۱۶ دارند. در واقع ما روش تکرارشونده پیشنهادی را تا ۴ مرحله ادامه دادیم و اندازه شبکه هر مرحله نزدیک یک‌چهارم اندازه شبکه‌های مورد مقایسه است و بنابراین مدل نهایی از نظر تعداد پارامتر با روش‌های پیشین مورد مقایسه برابری می‌کند. آموزش بر اساس روش نزول در راستای گرادیان^۳ است و بهینه‌ساز استفاده‌شده Adam [۲۶] با نرخ یادگیری ۰/۰۰۱ و اندازه بسته ۶۴ بوده است. همچنین بستر پیاده‌سازی چارچوب تنسورفلو^۴ است.

برای افزایش اعتبار نتایج، سه بار مجموعه داده تصادفی به دسته‌های آموزش، اعتبارسنجی و آزمون تقسیم می‌شود و طبق روال گفته‌شده آموزش انجام می‌شود. در نهایت میانگین و انحراف این سه آزمایش روی مجموعه آزمون گزارش شده است.

۴-۵ نتایج

مطابق آنچه که در بخش‌های پیشین گفته شد، روش پیشنهادی با روش‌های MLE، MaliGAN، SeqGAN و RankGAN روی سه مجموعه داده EMNLP۲۰۱۷ WMT News، COCO Captions و Chinese Poems مقایسه می‌شود. برای ارزیابی معیارهای BLEU-۲ تا BLEU-۵ به عنوان پرستفاده‌ترین معیارها در زمینه ارزیابی تولید متن مورد بررسی قرار گرفته‌اند. شکل‌های ۳ تا ۵ و جداول ۱ تا ۳ نتایج به دست آمده را نشان می‌دهد. طبق این نتایج روش پیشنهادی در همه موارد به جز BLEU-۲ روی مجموعه داده EMNLP۲۰۱۷ توانسته به بهبود قابل توجهی دست پیدا کند. یکی از مهم‌ترین دلایل عملکرد بهتر روش پیشنهادی در مقایسه با دیگر روش‌های تولید متن مبتنی بر GAN نحوه بهینه‌سازی در روش پیشنهادی است که موجب می‌شود برای به روز رسانی مولد نیاز به انتقال گرادیان تمیزدهنده به مولد که یکی از چالش‌های روش‌های پیشین است نداشته باشیم. همچنین روش



شکل ۴: نتایج روش‌های مختلف بر حسب BLEU-۲ تا BLEU-۵ همراه میزان انحراف معیار بر روی مجموعه داده EMNLP۲۰۱۷ WMT News.

تمامی جملات تولیدشده عدد نهایی این معیار را نشان می‌دهد. نحوه محاسبه امتیاز نهایی در رابطه زیر نشان داده شده است

$$Score = \frac{1}{N} \sum_{i=1}^N BLEU(x_i, T) \quad (18)$$

که در آن $BLEU(x, y)$ به معنی معیار BLEU برای جمله x و مجموعه مرجع y است. همچنین T نشان‌دهنده مجموعه آزمون و x_i نشان‌دهنده i امین نمونه تولیدشده است.

۳-۵ بیکربندی آزمایش‌ها

برای بررسی عملکرد روش پیشنهادی تعدادی از معروف‌ترین یا بهترین روش‌ها را انتخاب و با آن مقایسه کردیم. از بین روش‌های مبتنی بر GAN روش SeqGAN به عنوان اولین روش و روش‌های RankGAN و MaliGAN به عنوان قوی‌ترین روش‌های تولید متن مبتنی بر GAN انتخاب شدند. همچنین MLE به عنوان قوی‌ترین روش پایه برای تولید متن در نظر گرفته شد. برای روش‌های MLE، MaliGAN، SeqGAN و RankGAN از کدهای پیاده‌سازی شده در چارچوب معرفی شده در [۲۵] استفاده گردیده است. شبکه مولد استفاده‌شده در تمام روش‌ها، یک شبکه بازگردنده LSTM است. اندازه لایه مخفی شبکه ۶۴ و اندازه فضای ویژگی ورودی شبکه بازگردنده نیز ۶۴ در نظر گرفته شده است. همچنین اندازه بسته^۱ برابر ۶۴ استفاده شده است. باقی تنظیمات روش‌ها، مشابه کد

2. Epoch
3. Gradient Descent
4. TensorFlow

1. Batch Size

جدول ۳: نتایج روش‌های مختلف بر حسب BLEU-۲ تا BLEU-۵ در مجموعه داده CHINESE POEMS.

روش	BLEU-۲	BLEU-۳	BLEU-۴	BLEU-۵
MLE	۰٫۰۶	۰٫۲۳۲	۰٫۱۰۹	۰٫۰۵
	±۰٫۰۰۲	±۰٫۰۰۳	±۰٫۰۰۱	±۰٫۰۰۰
MaliGAN	۰٫۶۳۱	۰٫۲۶۸	۰٫۱۰۲	۰٫۰۵۶
	±۰٫۰۰۳	±۰٫۰۰۶	±۰٫۰۰۲	±۰٫۰۰۱
SeqGAN	۰٫۶۷۶	۰٫۳۰۴	۰٫۱۱۵	۰٫۰۶۱
	±۰٫۰۰۵	±۰٫۰۰۸	±۰٫۰۰۳	±۰٫۰۰۲
RankGAN	۰٫۶۷۵	۰٫۳۱۳	۰٫۱۱۷	۰٫۰۶۲
	±۰٫۰۰۹	±۰٫۰۰۹	±۰٫۰۰۲	±۰٫۰۰۱
Ours	۰٫۷۲۹	۰٫۴۳۹	۰٫۱۹۶	۰٫۰۹۵
	±۰٫۰۱۸	±۰٫۰۱۷	±۰٫۰۰۴	±۰٫۰۰۲

جدول ۴: نتایج روش پیشنهادی بر روی مجموعه داده فارسی.

مجموعه داده	BLEU-۲	BLEU-۳	BLEU-۴	BLEU-۵
شعر فارسی	۰٫۸۳۳	۰٫۸۳۳	۰٫۸۳	۰٫۸۲۴
همشهری	۰٫۹۵۶	۰٫۸۵۹	۰٫۶۷۸	۰٫۴۷

کاهش اندازه واژگان وجود دارد، از این بین ۴۰۶۲۵ جمله جدا شده است به طوری که اندازه واژگان برابر ۵۰۰۰ باشد. برای این مجموعه داده نیز ده گام یا تکرار در نظر گرفته شده و شبکه‌ای با اندازه لایه مخفی و فضای ویژگی ورودی ۱۲۸ در نظر گرفته شده است.

جدول ۴ نشان‌دهنده نتایج عددی روش پیشنهادی بر روی این دو مجموعه داده فارسی است. نمونه‌هایی از نتایج روش پیشنهادی بر روی مجموعه داده اشعار فردوسی در جدول ۵ گزارش شده است. همچنین نمونه‌هایی از نتایج روش بر روی مجموعه داده همشهری در جدول ۶ گزارش شده است. همان طور که در نتایج به دست آمده بر روی این دو مجموعه مشخص است روش پیشنهادی توانسته در تولید متون عملکرد خوبی از خود نشان دهد.

۶- جمع‌بندی

در این مقاله یک روش تولید متن مبتنی بر شبکه‌های مقابله‌ای معرفی شد. راهکار پیشنهادی شامل دو گام می‌شود، در یک گام با آموزش تمیزدهنده، نسبت چگالی توزیع واقعی به توزیع فعلی تخمین زده می‌شود و در گام دیگر با نسبت تخمین زده شده، توزیع مولد به روز رسانی می‌گردد. به عبارت دیگر در گام آموزش، تمیزدهنده تفاوت‌های داده‌های تولیدی توسط مولد با داده‌های اصلی یاد گرفته می‌شود و در گام دیگر با رابطه‌ای که فرم بسته دارد، این دانش به مولد منتقل شده و این روال به صورت تکرارشونده انجام می‌شود. در این روش با یک رویکرد یادگیری جمعی همه تمیزدهنده‌های یاد گرفته شده در گام‌های پیشین برای تخمین مولد در گام بعدی به کار گرفته می‌شوند. نتایج آزمایش‌ها نشان می‌دهد که روش پیشنهادی در مقایسه با روش‌های پیشین مبتنی بر GAN برای تولید متن و همچنین در مقایسه با MLE به متن‌های با کیفیت بالاتری دست پیدا کرده است. در آینده قصد داریم روش پیشنهادی را برای تولید متن در حالت شرطی جهت استفاده در سیستم‌های پرسش و پاسخ و دیالوگ گسترش دهیم.

جدول ۱: نتایج روش‌های مختلف بر حسب BLEU-۲ تا BLEU-۵ در مجموعه داده COCO CAPTIONS.

روش	BLEU-۲	BLEU-۳	BLEU-۴	BLEU-۵
MLE	۰٫۹۰۵	۰٫۷۴۵	۰٫۵۴۷	۰٫۳۷۳
	±۰٫۰۰۱	±۰٫۰۰۳	±۰٫۰۰۳	±۰٫۰۰۳
MaliGAN	۰٫۹۱۳	۰٫۷۶۸	۰٫۵۸۴	۰٫۴۰۷
	±۰٫۰۰۴	±۰٫۰۱۰	±۰٫۰۱۷	±۰٫۰۱۹
SeqGAN	۰٫۹۴۲	۰٫۸۲۱	۰٫۶۴	۰٫۴۵
	±۰٫۰۰۶	±۰٫۰۱۴	±۰٫۰۲۱	±۰٫۰۲۹
RankGAN	۰٫۹۴۵	۰٫۸۲۷	۰٫۶۵۲	۰٫۴۷
	±۰٫۰۱۰	±۰٫۰۲۶	±۰٫۰۴۰	±۰٫۰۴۱
Ours	۰٫۹۹۶	۰٫۹۸۹	۰٫۹۵۴	۰٫۸۶۸
	±۰٫۰۰۰	±۰٫۰۰۱	±۰٫۰۰۶	±۰٫۰۱۶

جدول ۲: نتایج روش‌های مختلف بر حسب BLEU-۲ تا BLEU-۵ در مجموعه داده EMNLP۲۰۱۷ WMT NEWS.

روش	BLEU-۲	BLEU-۳	BLEU-۴	BLEU-۵
MLE	۰٫۸۴۸	۰٫۵۶۷	۰٫۲۸۹	۰٫۱۳۸
	±۰٫۰۰۲	±۰٫۰۰۵	±۰٫۰۰۵	±۰٫۰۰۲
MaliGAN	۰٫۸۶۳	۰٫۶۱۳	۰٫۳۴۶	۰٫۱۶۷
	±۰٫۰۰۶	±۰٫۰۱۸	±۰٫۰۲۳	±۰٫۰۱۸
SeqGAN	۰٫۸۶۴	۰٫۶۷۵	۰٫۴۱۶	۰٫۲۰۷
	±۰٫۰۰۷	±۰٫۰۵۵	±۰٫۰۴۲	±۰٫۰۲۷
RankGAN	۰٫۷۹۹	۰٫۶۰۲	۰٫۳۴۸	۰٫۱۷۴
	±۰٫۰۳۰	±۰٫۰۳۶	±۰٫۰۳۵	±۰٫۰۱۸
Ours	۰٫۸۰۹	۰٫۷۰۶	۰٫۵۷۳	۰٫۳۹۴
	±۰٫۰۱۰	±۰٫۰۴۴	±۰٫۰۴۹	±۰٫۰۴۰

پیشنهادی به خاطر عملکرد جمعی در هر گام به دنبال آن است که با استفاده از همه تمیزدهنده‌های یاد گرفته شده تا کنون بهترین مولد را یاد بگیرد و به این ترتیب از تجربه همه گام‌های پیشین استفاده می‌کند.

۵-۵ نتایج روش پیشنهادی روی مجموعه داده فارسی

برای ارزیابی روش پیشنهادی در تولید متون فارسی، دو مجموعه داده جمع‌آوری شده است. مجموعه اول اشعار فردوسی است که از سایت گنجور^۱ جمع‌آوری شده و پیش‌پردازش‌هایی برای حذف کاراکترهای خارج زبان فارسی و جایگذاری با کاراکتر درست انجام شده است. در نهایت ۴۹۶۰۹ بیت به دست آمده که با در نظر گرفتن هر کدام از این ابیات به عنوان یک جمله، آموزش انجام می‌شود. آموزش بر روی این مجموعه داده به صورت کاراکتری انجام شده است. آموزش به وسیله ۱۰ گام یا تکرار روش پیشنهادی با شبکه‌ای با اندازه لایه مخفی ۱۲۸ و فضای ویژگی ورودی ۳۲ بوده است.

مجموعه دوم اخبار سایت روزنامه همشهری^۲ است. اخبار از روی این سایت جمع‌آوری شده و سپس به وسیله کتابخانه NLTK^۳ جملات آن جدا شده است. در نتیجه ۸۷۰۳۰۹ جمله غیر تکراری با طول بین ده تا چهل کلمه به دست آمده است. از آنجا که مشابه دیگر روش‌ها نیاز به

1. ganjoor.net
2. www.hamshahrionline.ir
3. www.nltk.org

Int. Conf. on Learning Representations, ICLR'17, 20 pp., Toulon, France, 24-26 Apr. 2017.

- [9] A. M. Lamb, et al., *Professor Forcing: A New Algorithm for Training Recurrent Networks*, in *Advances in Neural Information Processing Systems 29*, D. D. Lee, et al., Editors. 2016, Curran Associates, Inc. pp. 4601-4609.
- [10] Y. Zhang, et al., "Adversarial feature matching for text generation," in *Proc. of the 34th Int. Conf. on Machine Learning, ICML'17*, pp. 4006-4015, Sydney, Australia, Aug. 2017.
- [11] G. L. Guimaraes, et al., Objective-Reinforced Generative Adversarial Networks (ORGAN) for Sequence Generation Models. CoRR, 2017. abs/1705.10843.
- [12] K. Lin, et al., "Adversarial ranking for language generation," *Advances in Neural Information Processing Systems*, pp. 3158-3168, Long Beach, CA, USA, 4-9 Dec. 17.
- [13] J. Guo, et al., "Long text generation via adversarial training with leaked information," in *Proc. of the 32nd AAAI Conf. on Artificial Intelligence, AAAI'18, the 30th Innovative Applications of Artificial Intelligence, IAAI'18, and the 8th AAAI Symp. on Educational Advances in Artificial Intelligence, EAAI'18*, pp. 5141-5148, New Orleans, Louisiana, USA, Feb. 2018.
- [14] T. Che, et al., Maximum-Likelihood Augmented Discrete Generative Adversarial Networks, arXiv preprint arXiv:1702.07983, 2017.
- [15] I. Gulrajani, F. Ahmed, M. Arjovsky, V. Dumoulin, and A. C. Courville., "Improved training of wasserstein GANs," in *Advances in Neural Information Processing Systems 30*, I. Guyon, et al., Editors. 2017, Curran Associates, Inc. p. 5767-5777.
- [16] O. Press, A. Bar, B. Bogin, J. Berant, and L. Wolf., *Language Generation with Recurrent Generative Adversarial Networks without Pre-Training*, arXiv preprint arXiv:1706.01399, 2017.
- [17] S. Subramanian, S. Rajeswar, F. Dutil, C. Pal, and A. Courville, "Adversarial generation of natural language," in *Proc. of the 2nd Workshop on Representation Learning for NLP*, pp. 241-251, Vancouver, Canada, 3-3 Aug. 2017.
- [18] A. S. Vezhnevets, et al., "FeUdal networks for hierarchical reinforcement learning," in *Proc. of the 34th Int' Conf. on Machine Learning, ICML 2017*, vol. 70, pp. 3540-3549, Sydney, Australia, Aug. 2017.
- [19] R. D. Hjelm and A. Jacob, "Boundary-seeking generative adversarial networks," in *Proc. Int. Conf. on Learning Representations*, 17 pp., Apr. 2018.
- [20] M. H. Moghadam and B. Panahbehagh, *Creating a New Persian Poet Based on Machine Learning*, Computing Research Repository (CoRR), 2018. abs/1810.06898.
- [21] S. H. Hosseini Saravani, M. Bahrani, H. Veisi, and S. Besharati, "Persian language modeling using recurrent neural networks," in *Proc. 9th Int. Symp. on Telecommunications, IST'18*, pp. 207-210, Tehran, Iran, 17-19 Dec. 2018.
- [22] M. Sugiyama, T. Suzuki, and T. Kanamori, "Density-ratio matching under the Bregman divergence: a unified framework of density-ratio estimation," *Annals of the Institute of Statistical Mathematics*, vol. 64, no. 5, pp. 1009-1044, 2012.
- [23] X. Zhang and M. Lapata, "Chinese poetry generation with recurrent neural networks," in *Proc. of the Conf. on Empirical Methods in Natural Language Processing, EMNLP'14*, pp. 670-680, Doha, Qatar, 25-29 Oct. 2014.
- [24] K. Papineni, S. Roukos, T. Ward, and W. -J. Zhu, "Bleu: a method for automatic evaluation of machine translation," in *Proc. of the 40th Annual Meeting of the Association for Computational Linguistics, ACL'02*, pp. 311-318, Philadelphia, PA, USA, Jul. 2002.
- [25] Y. Zhu, et al., "Txygen: a benchmarking platform for text generation models," in *Proc. 41st Int. ACM SIGIR Conference on Research & Development in Information Retrieval, SIGIR'18*, pp. 1097-1100, Jun. 2018.
- [26] D. P. Kingma and J. Ba, *Adam: A Method for Stochastic Optimization*, CoRR, 2014. abs/1412.6980.

احسان منتزهی تحصیلات خود را در مقاطع کارشناسی از دانشگاه خوارزمی در رشته مهندسی کامپیوتر در سال ۱۳۹۵ به پایان رساند. وی بلافاصله دوره کارشناسی ارشد را در رشته مهندسی کامپیوتر، گرایش هوش مصنوعی، در دانشگاه صنعتی شریف آغاز کرد و در سال ۹۷ دوره کارشناسی ارشد خود را با موفقیت به اتمام رساند. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: یادگیری ژرف، مدل‌های مولد، تولید متن، مدل‌های احتمالاتی.

جدول ۵: نمونه‌هایی از ابیات تولیدشده بر روی مجموعه داده اشعار فردوسی.

به پیش سپاه اندر آمد ز جای	که ای نامور شاه را دل ز جای
به پیران چنین گفت کای پرخرد	که از من بدین داستان بگذرد
بدو گفت بهرام کای نامجوی	به دل گفت کای در جهان کینه‌جوی
برآمد ز ایوان شاه آمدند	به نزدیک او با سپاه آمدند
به کار اندر آمد ز دریای خون	بگویم که باشد به دل پر ز خون
بدو گفت بر من بدی در جهان	زمین را همی داشت اندر نهان
بدین گونه با او سپه را بخواند	سوی شاه گردن فراوان براند
به روی اندر آمد ز من در جهان	ز توران به درگاه شاه جهان
چو بشنید ازو بازگشتن به راه	بیاراست لشکر برآمد ز راه
بدو گفت بازار ایران زمین	که ای پهلوان سر به سر بر زمین
به داد و به دیدار او شد سپاه	به پیش سپاهش به تخت و کلاه
بران کوه بر شد ز هر سو سپاه	که بیژن نیاید به پیش سپاه
به پیش اندر آمد سوی کارزار	که از کار او در جهان کارزار
به ایوان بیاراست گرد سپاه	چو خورشید تابان به درگاه شاه
برآمد ز هر سو که بر ماه روی	ز من بر تو این در جهان نیست روی
بر این شاهان به ایران زمین	ز تبغ و ز پیل ژبان بر زمین
به نزد سیاوش به درگاه شاه	چو از پیش او شد سر از مهر شاه
به داد و به دین اندر آمد سپاه	که از من نهاده به پیش سپاه
بران کوه برخاست اواز او	ز گیتی به درگاه برخاست او
برین گونه تا بر سرش پر ز خون	زبانش بهر کار دل پر ز خون
برآمد ز هر دو سپه را بخواند	ز گرگین و گردان لشکر براند
برآمد خروشیدن از مرد راست	برانگیخت ان پادشاهی مراست
بر او را به نزدیک شاه جهان	که از دیده باشد زمانی نهان
به ایوان بیاراست گرد سپاه	که مندر به خورشید و ماه و سپاه
بدو گفت رستم که ای نامجوی	که ای نامداران و پرخاشجوی
به ایوان بیامد سپه را ز جای	به دل پر ز خون اندر آمد به جای

مراجع

- [1] F. Huszar, How (not) to Train your Generative Model: Scheduled Sampling, Likelihood, Adversary? Computing Research Repository (CoRR), 2015. abs/1511.05101.
- [2] I. J. Goodfellow, et al., "Generative adversarial nets," in *Proc. Advances in Neural Information Processing Systems 27: Annual Conf. on Neural Information Processing Systems*, vol. 2, pp. 2672-2680, Montreal, Canada, Dec. 2014.
- [3] I. J. Goodfellow, *NIPS 2016 Tutorial: Generative Adversarial Networks*, Computing Research Repository (CoRR), 2017. abs/1701.00160.
- [4] L. Yu, W. Zhang, J. Wang, and Y. Yu, "SeqGAN: sequence generative adversarial nets with policy gradient," in *Proc. of the 31st AAAI Conf. on Artificial Intelligence*, pp. 2852-2858, San Francisco, CA, USA, Feb. 2017.
- [5] S. Bengio, O. Vinyals, N. Jaitly, N. Shazeer, "Scheduled sampling for sequence prediction with recurrent neural networks," *Advances in Neural Information Processing Systems*, vol. 1, pp. 1171-1179, Montreal, Canada, 7-12 Dec. 2015.
- [6] M. J. Kusner and J. M. Hernandez-Lobato, *GANs for Sequences of Discrete Elements with the Gumbel-softmax Distribution*, arXiv e-prints, 2016: p. arXiv:1611.04051-arXiv:1611.04051.
- [7] E. Jang, S. Gu, and B. Poole, "Categorical reparameterization with gumbel-softmax," in *Proc. Int. Conf. on Learning Representations, ICLR'17*, 12 pp., Toulon, France, 24-26 Apr. 2017.
- [8] C. J. Maddison, A. Mnih, and Y. W. The, "The concrete distribution: a continuous relaxation of discrete random variables," in *Proc. 5th*

جدول ۶: نمونه‌هایی از جملات تولیدشده بر روی مجموعه داده اخبار همشهری.

وی در ادامه گفت: این طرح در حال بررسی است و در این زمینه نیز به صورت آزمایشی در حال انجام است. وی افزود: به همین دلیل در این زمینه هم به هر دو موضوع نگاه می‌کنیم. در این میان دو طرف در این دوره از رقابت‌ها به صورت مستقیم از دور رفت و در مرحله گروهی به مصاف هم می‌روند. این در حالی است که این موضوع باعث می‌شود که مردم در این زمینه به آنها کمک کنند. ما در این زمینه هیچ مشکلی نداریم. این شورا در ادامه به این موضوع اشاره کرد و افزود: این طرح در مجلس شورای اسلامی به تصویب رسید. این در حالی است که در حال حاضر حدود ۷۰ درصد از ذخایر نفت و گاز در کشور و افزایش تولید ناخالص ملی و مناطق دیگر نیز در حال حاضر در این زمینه است. وی افزود: در این شرایط ما باید تلاش کنیم تا این موضوع را درک کنند. در چنین شرایطی ما می‌توانیم به این سمت برویم که در این زمینه کار کنیم. وی همچنین از پیشنهاد حمایت از این طرح در مجلس شورای اسلامی خبر داد. در این میان هم یک سری کارها را انجام داده‌ایم. در نهایت هم با این پیروزی ۷ امتیازی شد و در صدر جدول رده‌بندی قرار گرفت. البته این موضوع در حال حاضر هم در حال انجام است و امیدواریم این موضوع را به طور جدی دنبال کنیم. وی ادامه داد: ما در این زمینه بحث و گفت‌وگو کرده‌ایم. وی ادامه داد: ما در حال بررسی و کار هستیم و امیدواریم بتوانیم در این زمینه هم تصمیم بگیریم. در این مرحله به طور رسمی از ابتدای سال جاری میلادی تا کنون حدود ۲۰ درصد رسیده است. این در حالی است که در حال حاضر حدود ۲۰ درصد از سهام این شرکت در بورس عرضه می‌شود. وی افزود: در این زمینه هم باید به این مسائل نگاه کنیم و از آن هم بتوانیم در این زمینه استفاده کنیم. این در حالی است که در حال حاضر حدود ۷۰ درصد از این میزان کاهش یافته است. به همین دلیل باید به این موضوع توجه کرد. این در حالی است که در این نشست به دنبال مذاکرات با کشورهای ۵+۱ در مورد مذاکرات هسته‌ای ایران و آمریکا با یکدیگر دیدار خواهند کرد. ما در حال حاضر در این زمینه باید در چارچوب قانون عمل کنیم. در این شرایط ما هم از نظر روحی اهمیت زیادی داریم. به این ترتیب در نهایت با نتیجه یک بر صفر به سود ایران به پایان رسیده است. در واقع می‌توان گفت در این میان دو عامل مهم است. وی افزود: در این صورت باید از این طریق یک فرصت برای مردم فراهم شود. در این گزارش آمده است: ما در حال بررسی هستیم و باید به این موضوع توجه کنیم. این در حالی است که برخی از کشورهای اروپایی نیز در این زمینه حمایت می‌کنند. در این مرحله یک‌چهارم نهایی هم از روز دوشنبه ۲۵ اردیبهشت ماه به وقت محلی آغاز می‌شود. ما در حال حاضر حدود ۲۰ درصد از این کار را انجام داده‌ایم. این موضوع در حال حاضر هم در حال توسعه است و به دنبال آن هستیم. این مسئله باعث می‌شود که در شرایط کنونی هم به این مسئله توجه کنند. این در حالی است که در این نشست با حضور نمایندگان کنگره آمریکا در خصوص این موضوع تاکید کرد. به گفته وی در سال جاری حدود ۲۰۰ میلیارد تومان در بورس عرضه می‌شود. همچنین در این زمینه نیز بیش از ۱۰ هزار واحد مسکن در اختیار دارد. این در حالی است که دولت باید در این زمینه به وظایف خود عمل کند. در این مدت هم در حال حاضر مردم و مسئولان باید به این موضوع توجه کنند. به گفته وی از این تعداد در سال تحصیلی جاری در حال حاضر حدود ۱۰۰ میلیون نفر در این مناطق هستند.

مهديه سلیمانی باغشاه در سال ۱۳۷۸ دوره کارشناسی مهندسی کامپیوتر را در دانشگاه صنعتی شریف آغاز کرد و در سال ۱۳۸۲ مدرک کارشناسی خود را اخذ کرد و بلافاصله در مقطع کارشناسی ارشد رشته مهندسی کامپیوتر، گرایش هوش مصنوعی دانشگاه صنعتی شریف مشغول به تحصیل شد و در سال ۱۳۸۴ دوره کارشناسی ارشد را به اتمام رساند و تحصیل در دوره دکترای مهندسی کامپیوتر را در دانشگاه صنعتی شریف آغاز کرد و موفق به اتمام این دوره در سال ۱۳۸۹ شد. وی از سال ۱۳۹۱ در دانشکده مهندسی کامپیوتر دانشگاه صنعتی شریف به عنوان عضو هیأت علمی مشغول به فعالیت شد و اینک نیز عضو هیأت علمی این دانشکده می‌باشد. زمینه‌های علمی مورد علاقه نام‌برده شامل زمینه‌های یادگیری ماشین، یادگیری ژرف و مدل‌سازی احتمالاتی است.